



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

공학석사학위논문

사용자 특성 정보를 활용한 스마트폰 데이터 기반의 상황 인지 성능 향상

Enhancement of high-level context recognition performance
based on smartphone data using user information

2018 년 8 월

서울대학교 대학원

산업공학과

이 재 홍

사용자 특성 정보를 활용한 스마트폰 데이터 기반의 상황 인지 성능 향상

Enhancement of high-level context recognition
performance based on smartphone data using user
information

지도교수 박 종 현

이 논문을 공학석사 학위논문으로 제출함

2018 년 6 월

서울대학교 대학원

산업공학과

이 재 홍

이재홍의 공학석사 학위논문을 인준함

2018 년 6 월

위 원 장 _____ 조 성 준 _____ (인)

부위원장 _____ 박 종 현 _____ (인)

위 원 _____ 이 재 욱 _____ (인)

초록

개인화 기기인 스마트폰의 사용이 보편화되고 있고 이를 이용한 다양한 종류의 서비스가 등장함에 따라, 사용자의 상황에 따른 맞춤형 서비스에 대한 요구가 증가하고 있다. 스마트폰은 음성 통화나 문자 메시지 등과 같은 기존의 휴대전화의 기능 외에도 데이터 통신이나 다중 센서 데이터 등을 활용 가능한 애플리케이션의 활용이 가능한 개인용 컴퓨터로서의 역할을 수행하고 있다. 많은 수의 스마트폰 사용자들은 일상생활 대부분의 시간에 스마트폰을 휴대하고 있기 때문에, 스마트폰으로부터 수집할 수 있는 데이터를 활용하여 사용자의 상황을 인지하는 연구들과 사용자 특성 정보를 추론하는 연구들이 다양하게 진행되어왔다. 센서 데이터를 통해 물리적 운동에 따라 구분되는 저수준 컨텍스트를 인지하는 연구에 비해, 사회나 문화적 차이에 따라 의미가 달라질 수 있는 고수준 컨텍스트 인지에 대한 연구는 상대적으로 물리 센서 데이터의 의존도가 낮기 때문에, 인지 난이도도 높고 아직까지 상대적으로 미진하였다. 고수준 컨텍스트 인지 정확도가 좋을수록 상황별 맞춤형 서비스의 다양화나 정교화에 있어서 활용 방안이 다양하다. 이에 본 연구에서는 사용자 특성에 따라 센서 데이터의 분포가 달라진다는 점을 통해, 센서 데이터 기반의 사용자 상황 인지 모형에 사용자 특성 정보를 함께 사용하여 사용자의 고수준 컨텍스트 상황 인지 모형의 정확도를 향상시킬 수 있는 기법을 제안한다.

본 연구에서 제안하는 기법은 두 단계로 구성된다. 그 첫번째 단계로, 순간적으로 획득이 가능한 스냅샷 데이터를 이용하기 때문에 즉시 추론이 가능한 사용자 특성 정보 추론을 수행한다. 두번째 단계로는, 첫 단계에서 얻은 사용자 특성 정보를 인지 대상이 되는 센서 데이터와 병합하여 상황 인지 모형의 입력값으로 사용하여 인지 대상의

사용자의 상황 인지를 수행한다.

사용자 특성 추론 모형은 스냅샷 데이터인 사용자의 스마트폰 애플리케이션 목록으로부터 생성한 요인벡터를 이용해 학습을 수행하여 사용자 특성 정보를 추론한다. 상황 인지 모형은 가속도 센서 데이터와 오디오 센서 데이터를 이용하여 앙상블 학습 방법의 일종인 랜덤 포레스트 분류 모형을 통해 수면, 식사, 수업, 공부, 음주, 이동의 총 여섯 가지 상황을 인지 한다.

자체 제작한 애플리케이션을 통해 100명의 피실험자들로부터 실험 데이터를 수집하고 제안 기법의 성능을 확인하였다. 여섯 가지 상황과 열두 가지 사용자 특성 정보를 조합하여 각 특성 정보가 클래스 별로 인지 성능에 미치는 영향력을 살펴보았다. 그 결과, 제안 기법을 통해 기존의 상황 인지 모형에서 13%의 성능 향상을 확인할 수 있었다.

주요어: 상황 인지, 스마트폰 물리 센서, 사용자 특성, 스마트폰 애플리케이션 설치 목록, 랜덤 포레스트, Doc2Vec, 앙상블

학번: 2016-21118

목차

초록	i
목차	v
표 목차	vi
그림 목차	vii
제 1 장 서론	1
1.1 연구 배경	1
1.2 연구 목적	3
1.3 연구 내용	4
제 2 장 배경 이론 및 관련 연구	5
2.1 배경 이론	5
2.1.1 랜덤 포레스트	5
2.1.2 Doc2Vec	8
2.1.3 TF-IDF	11
2.2 관련 연구	13
2.2.1 사용자 상황 인지	13
2.2.2 사용자 특성 정보 추론	15
제 3 장 제안 기법	16

3.1	전체 과정	16
3.2	데이터 전처리	18
3.2.1	데이터 수집 구간 동기화	18
3.2.2	가속도 센서 데이터 보정	20
3.2.3	오디오 센서 데이터 전처리	22
3.3	인지 모형	23
3.3.1	사용자 상황 인지	23
3.3.2	사용자 특성 정보 추론	23
제 4	장 실험 및 결과	25
4.1	실험 데이터	25
4.1.1	데이터 수집용 애플리케이션	25
4.1.2	데이터 수집 실험	27
4.2	실험 설계	29
4.3	실험 환경 및 평가 지표	30
4.3.1	실험 환경	30
4.3.2	평가 지표	31
4.4	실험 결과	32
4.4.1	사용자 상황 인지 모형 최적 매개변수	32
4.4.2	사용자 특성 정보 적용 여부	34
4.4.3	사용자 특성 정보 추론 실험	38
4.4.4	실제 추론한 사용자 특성 정보를 적용한 상황 인지 모형의 성능	39
제 5	장 결론	41

5.1 요약 및 연구 의의	41
5.2 향후 연구	43
참고문헌	44
Abstract	51

표 목차

표 2.1	스마트폰 센서를 이용한 연구 사례	13
표 4.1	수집 상황 컨텍스트 별 데이터 수집 주기	26
표 4.2	모달리티 별 데이터 수집 간격	26
표 4.3	사용자 특성 정보 항목별 분포	27
표 4.4	인지 성능 상위 10개의 사용자 상황 클래스	32
표 4.5	인지 성능 향상도 상위 10종의 사용자 상황 클래스	35
표 4.6	사용자 특성 정보 추론부의 최종 성능 도출	38
표 4.7	인지 성능 향상도 상위 10종의 사용자 상황 클래스	39

그림 목차

그림 2.1	결정 트리의 의사 결정 과정의 예시	5
그림 2.2	N개의 결정 트리들로 랜덤포레스트를 구성하는 배경의 예시 . .	6
그림 2.3	단어 임베딩의 예시	8
그림 2.4	벡터화된 단어들의 관계를 학습하는 과정[1]	9
그림 2.5	문서 D를 학습하는 Doc2Vec의 학습 과정[2]	10
그림 3.1	제안 기법의 전체 과정	16
그림 3.2	모듈별 센서들 간의 수집 타임스탬프 차이의 예	18
그림 3.3	선형 보간법을 활용하여 타임스탬프 값의 주기를 맞추는 과정의 예	19
그림 3.4	피실험자 별 정지 상태에서의 가속도 센서 측정량의 평균 및 표준 편차	20
그림 3.5	95번 피실험자의 일자 별 정지 상태에서의 평균 가속도 센서 값의 변화	20
그림 3.6	95번 피실험자의 가속도 센서 데이터 보정 예시	21
그림 4.1	SCDC의 메인 인터페이스	25
그림 4.2	사용자 특성 정보의 오류율에 따른 상황 인지 모형의 정확도 . .	34
그림 4.3	적용한 사용자 특성 별 상황 인지 모형의 성능 향상도	36
그림 4.4	제외한 사용자 특성 별 상황 인지 모형의 성능 향상도	36
그림 4.5	사용자 상황 클래스별 성능 향상도 분포	40

제 1 장 서론

1.1 연구 배경

개인화 기기인 스마트폰의 사용이 일반화 되고 있다. 스마트폰은 기존의 휴대 전화 기능인 음성 통화나 문자 메시지 등의 기능 외에 데이터 통신이나 다종 센서 데이터 등을 활용하는 다양한 애플리케이션의 활용이 가능하여 사실상, 휴대용 개인 컴퓨터의 역할을 수행하고 있다. 이에, 스마트폰 애플리케이션을 통한 다양한 서비스가 출시되어 사용자들의 편의성이 증대되고 있다.

다양한 애플리케이션 서비스가 등장함에 따라, 상황 인지 기반 서비스(context-aware service)에 대한 요구도 함께 다양해지고 있다. 여기서 상황 인지 서비스는 사용자의 생활습관이나 주요 관심사 등의 특성 정보 부터 사용자가 언제, 어디에서, 어떤 행동을 하고 있는가 등의 포괄적인 의미를 가지는 상황(context)에 따라 사용자에게 맞춤형 서비스를 제공하는 것을 의미한다. 그 예로, 사용자의 영화 취향을 파악하여 새로운 영화를 추천해주는 서비스나 과거 식당 이용 기록들을 통해 사용자에게 적절한 식당을 추천해주는 서비스[3] 등이 이에 해당한다.

스마트폰은 일상 생활 중의 대부분의 시간 동안 소지하고 있는 사람들이 많은 휴대용 기기이며 가속도, 자기장, 자이로스코프, 오디오 등의 다종 센서가 탑재되어 있기 때문에, 이를 바탕으로 스마트폰 사용을 통해 발생하는 데이터를 이용하여 다양한 종류의 상황을 인식하고자 하는 연구가 활발하게 진행되어 왔다. 걷기, 뛰기, 앉기 등의 단순한 움직임을 인지하는 저수준 상황 인지 (low-level context-aware)에서 부터 업무, 수업, 식사 등의 사회나 문화적인 차이에 따라 그 의미가 달라질 수 있는 복잡성이 높은

상황을 인지하는 고수준 상황 인지 (high-level context-aware)에 이르기까지 사용자의 상황을 인지하고자 하는 연구의 영역이 점점 확대되어 가고 있다. 사용자의 기본적인 정보를 얻기 위해 스마트폰 상에서 사용자가 작성한 글의 기록이나 웹 서핑 기록, 사회 연결망 서비스 (Social Network Service, SNS) 이용 기록 등의 데이터들로부터 사용자의 특성 정보를 추론하는 연구들이 수행되기도 했다.

사용자의 다양한 상황 정보를 인지할 수 있다면 맞춤형 서비스의 영역은 그에 따라 확장될 것이다. 예를 들어, 수업이 시작한 상황이거나 도서관에 들어가 공부를 하고 있는 상황의 사용자에게는 무음모드를 추천하거나 비행모드 활성화를 추천해줄 수 있고, 수면에 임하려는 상황의 사용자에게는 수면 패턴 분석 서비스를 추천해줄 수 있을 것이다. 식사 시간이 임박했을 때, 사용자의 키나 몸무게 등의 신체 정보에 따라 적절한 메뉴를 추천해주는 일이나 사용자가 모바일 애플리케이션을 통해 쇼핑을 하는 상황에서 취향이나 위치 기반의 상품을 추천하는 등 매우 다양한 맞춤형 서비스가 가능할 것이다.

1.2 연구 목적

본 연구는 센서 데이터 기반의 사용자 상황 인지 모형의 성능을 향상시키는 것을 그 목적으로 한다. 여기서 인지의 대상이 되는 상황은 수면, 식사, 수업, 공부, 음주, 이동의 여섯가지 상황으로, 사회나 문화적 차이에 의해 그 의미가 달라질 수 있는 고수준 컨텍스트에 해당하는 상황이다.

고수준 컨텍스트 인지는 저수준 컨텍스트 인지에 비해 스마트폰을 활용한 맞춤형 서비스에 그 활용방안이 높다. 본 연구에서의 인지 대상인 수면 상황의 경우, 자동으로 수면 패턴 분석 애플리케이션을 구동하는 데에 활용할 수 있고, 공부 상황 인지를 통해 스마트폰 사용자의 학습 시간 관리에 도움을 주는 일도 가능하다.

스마트폰에는 가속도 센서나 조도 센서 등의 다종 물리 센서들이 내장되어있다. 이러한 물리 센서들로부터 수집할 수 있는 데이터들을 활용하여 사용자의 상황을 인지한다. 특히, 물리 센서들이 요구하는 에너지 소모량은 높지 않은 편이기 때문에 필요한 상황에 짧은 시간 수집하는 것 만으로 사용자의 상황을 인지하는 데에 활용이 용이하다.

스마트폰은 개인용 컴퓨터나 고사양의 워크스테이션에 비해 연산력이 낮은 사양을 보유하고 있다. 본 연구에서 사용한 데이터는 스마트폰에서 발생한 데이터이고, 따라서 스마트폰 상에서 즉시 상황을 추론하고 활용하는 것이 가능한 기법을 연구하는 것이 그 목적이다.

1.3 연구 내용

본 연구에서는 랜덤 포레스트를 기반의 사용자 상황 인지 모형에 센서 데이터와 사용자 특성 정보를 함께 사용하여 인지 성능을 향상 시키는 기법을 제안한다. 스마트폰의 물리 센서의 한 종류인 가속도 데이터는 스마트폰에 직접적으로 가해지는 움직임을 포착하는 데에 활용도가 높은 정보이면서, 수집 환경에 따라 다양한 정도의 편향성이 가해지기 쉬운 데이터이다. 편향성을 낮추어 스마트폰의 기종이나 사용자의 습관에 따라 발생할 수 있는 가속도 센서 데이터의 편향성을 낮춰줄 수 있는 보간법을 제안한다.

실험을 위해 수집된 물리 센서 데이터는 수면, 식사, 수업, 공부, 음주, 이동의 여섯 가지 상황에 해당하는 데이터이고, 이들 중 '이동'을 제외한 상황들은 모두 피실험자의 스마트폰이 정지된 상태에서 수집되었다.

상황 인지 모형의 매개변수를 조정하여 최적의 인지 성능을 탐색하고, 제안한 기법이 실제로 효과가 있는지를 검증하는 실험 과정을 설계한다. 사용자 상황 인지 모형의 입력값으로 물리 센서 데이터와 사용자 특성 정보를 이어붙여 사용하는 방식을 제안한다. 일련의 전처리 과정들을 거친 데이터와 이를 통해 추출한 요인 데이터에 스냅샷 데이터로부터 생성한 요인 벡터를 통해 추론한 사용자 특성 정보를 함께 상황 추론 모형의 입력값으로 사용한다.

제 2장에서는 본 연구와 관련된 배경 이론들과 기존 연구들에 대한 정리를 하며 제 3장에서는 본 연구에서 제안하는 사용자 상황 추론 성능 향상 기법에 대해 서술한다. 제 4장에서는 실험 설계 과정과 결과를 정리하고, 마지막으로 제 5장에서는 결론을 도출하고 향후 연구 방향에 대해 논의한다.

제 2 장 배경 이론 및 관련 연구

2.1 배경 이론

2.1.1 랜덤 포레스트

랜덤 포레스트는 여러 개의 결정 트리들을 임의적으로 학습하는 방식의 모형으로, 회귀 문제나 분류 문제 모두에 사용할 수 있는 장점이 있다.

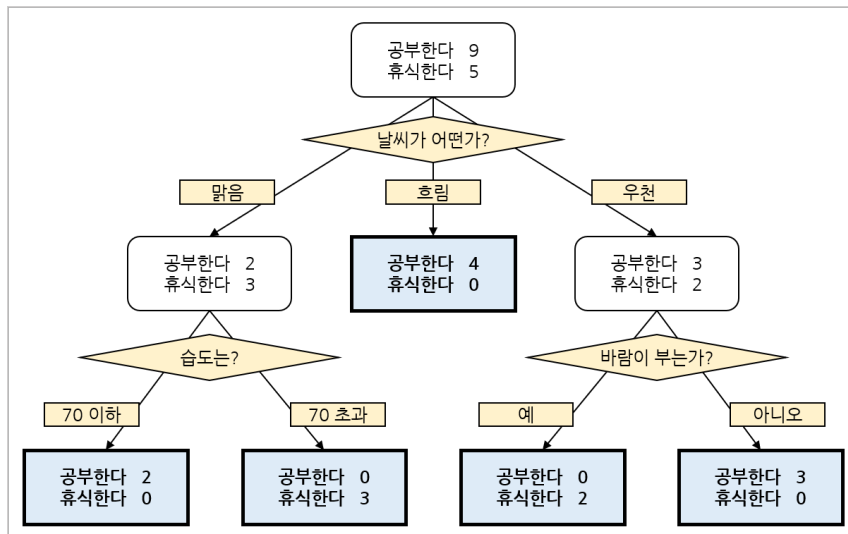


Figure 2.1: 결정 트리의 의사 결정 과정의 예시

랜덤 포레스트 모형의 기반이 되는 결정 트리는 그림 2.1의 예시처럼 데이터를 분석하여 이들 사이에 존재하는 패턴을 예측 가능한 규칙들의 조합으로 나타내며, 그 모양이 나무와 흡사한 성질로 인해 결정 트리라고 불리운다. 결정 트리는 학습 데이터의 특성에 따라 생성되는 결정 트리의 변동 폭이 커지기 때문에 그 성능의 변동 폭이 크며, 계층

적 접근방식 이기 때문에 중간에 오류가 발생할 경우 다음 단계로 오류가 지속적으로 전파된다는 단점을 지니고 있다.

이러한 결정 트리의 단점을 극복하기 위해, 임의의 노드 최적화(randomized node optimization, RNO)와 배깅(bootstrap aggregating, bagging)을 결합한 방법과 같은 classification and regression trees(CART)를 사용하여 상관관계가 없는 트리들로 포레스트를 구성하는 방법인 랜덤 포레스트 모형이 제안되었다[4]. 그림 2.2 같은 배깅 과정을 통해 학습 데이터와 같은 크기의 N개의 학습 데이터를 생성하고, 이를 각각의 N개의 의사결정 나무들이 학습하게 하여 그 결과를 평균 또는 투표 방식을 통해 하나의 랜덤 포레스트 모형으로 구성시킨다.

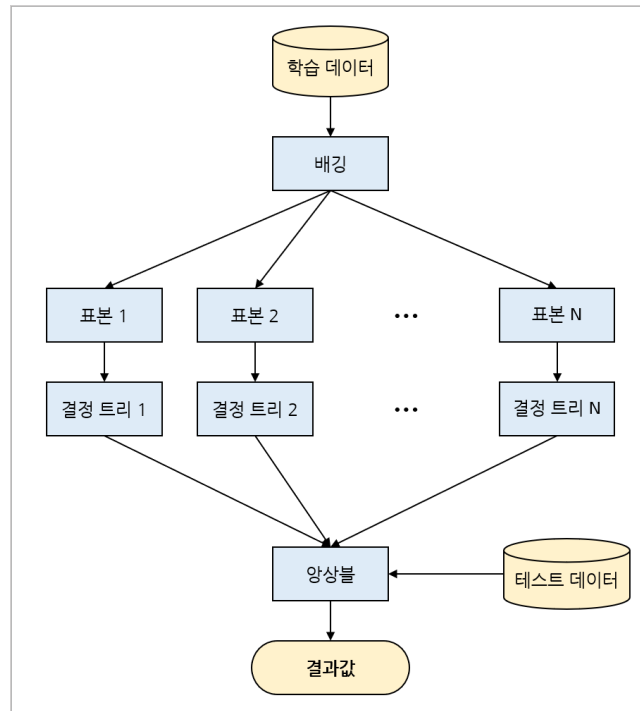


Figure 2.2: N개의 결정 트리들로 랜덤포레스트를 구성하는 배깅의 예시

임의 노드 최적화 같은 앙상블 기법은 결정 트리의 단점을 극복하도록 하여 좋은 일반화 성능을 갖도록 한다. 랜덤 포레스트 모형에 영향을 미치는 대표적인 매개변수로는 결정 트리의 개수와 최대 허용 깊이가 있다. 트리의 개수가 적을수록 모형을 학습하고 테스트하는 소요시간이 짧은 대신, 일반화 성능은 하락하여 틀린 결과값이 도출될 확률이 높아지고 트리의 개수가 많을수록 학습이나 테스트 시간은 증가하지만 결과값이 트리의 개수가 적은 모형에 비해 비교적 연속적이며 일반화 성능이 뛰어나다. 최대 허용 깊이는 하나의 트리에서 뿌리 노드부터 종단 노드까지 최대로 거칠 수 있는 노드의 개수로, 값이 작을수록 과소적합(underfitting)이 커지고 값이 클수록 과적합(overfitting)이 커지기 때문에 적절한 값을 선택하는 것이 중요하다.

랜덤 포레스트 모형은 마이크로소프트 연구소, 브라운 대학교, 캠브리지 대학교 연구팀의 다채널 자기공명영상(Multi-channel Magnetic resonance image)으로 촬영된 뇌 영상에서 고악성도 신경교종(High-grade gliomas)를 검출하는 연구[5]에 적용되어 그 유용성을 증명하기도 하였고, 엑스박스 360에서 사용되는 모션 캡처 주변기기인 키넥트[6]에서 카메라로부터 입력받은 이미지를 입력값으로 하여 사람의 신체 각 부위를 분류하는 용도로 사용되기도 하였다.

2.1.2 Doc2Vec

Doc2Vec[1]은 문서를 벡터로 표현하는 기법으로, 단어를 벡터로 표현하는 기법인 Word2Vec[2]을 확장하여 문장이나 단락 또는 전체 문서와 같이 보다 큰 단위의 텍스트에 적용하도록 연장시킨 기법이다.

Word2Vec은 인공 신경망을 이용한 연속적 단어 임베딩 학습 모형으로, '비슷한 분포를 가진 단어들은 비슷한 의미를 가진다'라는 의미의 언어학의 분산적 가정에 입각한 모형이다. 이 가정에서 분포가 의미하는 바는 단어들이 같은 문맥에서 등장한다는 것을 의미한다. 우선 학습 데이터에 등장하는 모든 고유 단어들을 대상으로 해당 단어는 1 나머지는 0으로 인코딩하는 원-핫 인코딩을 수행한다. 이 과정을 통해 벡터로 변환된 단어는 그리고 한 개의 은닉층을 가진 인공 신경망 모형을 이용하여 하나의 단어를 입력값으로 하여 문맥에서 인접한 위치에 등장하는 단어를 예측하도록 학습한다. 이때, 학습된 은닉층의 가중치를 단어를 나타내는 벡터로 사용하게 된다. 벡터화된 단어들의 관계는 그림 2.3의 예시처럼 아버지-어머니, 남성-여성 같은 단어들 간의 특정 의미 관계의 표현이 가능하다.




Figure 2.3: 단어 임베딩의 예시




Figure 2.4: 벡터화된 단어들의 관계를 학습하는 과정[1]

그림 2.4은 단어 벡터를 학습하는 과정을 도식화한 것이고, 이는 수식 (2.1)으로 표현될 수 있다.

$$\frac{1}{T} \sum_{t=1}^T \sum_{-c < j < c, j \neq 0} \log p(w_{t+j} | w_t) \quad (2.1)$$

수식 (2.1)에서 v_w 는 단어 w 를 나타내는 벡터이고, w_1, w_2, \dots, w_T 는 학습에 사용한 데이터에 나타난 일련의 T개의 단어들을 나타내고 Word2Vec은 수식 (2.1)의 로그 확률을 최대화 하는 v_w 를 학습한다. 이때, 추론할 단어들의 인접도에 따라 윈도우 크기인 c 를 변경시키며, 확률은 수식 (2.2)의 소프트맥스 함수를 이용한다.

$$p(w_O | w_I) = \frac{\exp(v'_{w_O}{}^T v_{w_I})}{\sum_{w=1}^W \exp(v'_w{}^T v_{w_I})} \quad (2.2)$$

수식 (2.2)에서 v_w 는 수식 (2.1)에서와 마찬가지로 단어 w 를 나타내는 벡터를 의미하며, W 는 등장한 모든 고유 단어의 수이고, w_I 는 입력값이 되는 단어, w_O 는 출력값이 되는 단어를 의미한다. v_w 는 인공 신경망의 입력층의 가중치, v'_w 는 인공 신경망의 출력층의 가중치이다. 즉, 수식 (2.2)에서 v_{w_I} 는 입력값이 되는 단어에 해당하는 인공 신경망 입력층의 가중치를 의미하고, v'_{w_O} 는 출력값이 되는 단어에 해당하는 인공 신경망 출력층의 가중치가 된다.

Doc2Vec은 상술한 Word2Vec과 유사하게, 해당 단어가 속한 문서의 원-핫 인코딩을 단어의 원-핫 인코딩과 함께 입력값으로 전달한다. 따라서 Doc2Vec은 그림 2.5에서 볼 수 있듯, 인접한 단어를 예측하는 인공 신경망 모델을 학습하는 과정에서, 해당 문서에 대한 입력층의 가중치를 문서 벡터로 사용하여 각각의 단어에 대한 가중치와 문서에 대한 가중치를 동시에 학습하게 된다.

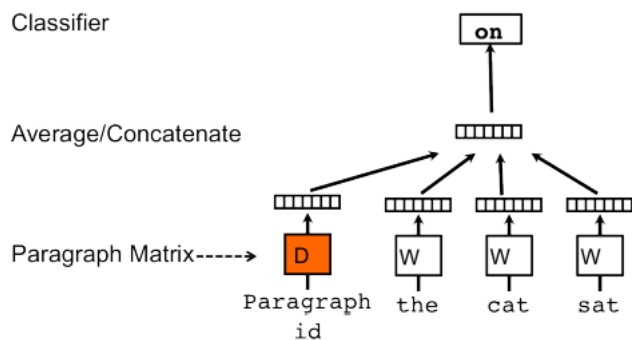


Figure 2.5: 문서 D를 학습하는 Doc2Vec의 학습 과정[2]

2.1.3 TF-IDF

TF-IDF(Term Frequency - Inverse Document Frequency)는 TF(Term Frequency)와 IDF(Inverse Document Frequency)가 결합된 알고리즘 명이다. 문서 내에서 사용된 모든 단어에 점수를 부여하여, 고유 단어들의 경중을 통계적으로 가려내 중요한 단어를 선별하고 추출하는 역할을 수행한다.

TF는 특정 단어가 특정 문서 내에서 얼마나 많이 나타났는지를 나타내는 값이고, IDF는 전체 문서 내에서 특정 단어가 등장한 빈도수의 역수값이다. 즉, TF-IDF는 특정 단어가 특정 문서에서 얼마나 자주 등장하였는가의 값과 전체 문서에서는 얼마나 적게 등장하였는가의 값을 곱한 값으로, 높은 수치를 가질 수록 특정 단어가 특정 문서의 핵심 단어로서의 역할을 하는가에 대한 지표가 될 수 있다.

d 를 특정 문서, w 를 특정 단어로 정의하면 TF는 수식 (2.3)으로 표현할 수 있고, 여기서 $f(w, d)$ 는 d 에 등장한 w 의 빈도를 의미한다.

$$\text{TF}(w, d) = 0.5 + \frac{0.5 \times f(w, d)}{\max\{f(w', d) : w' \in d\}} \quad (2.3)$$

전체 문서 D 에서 특정단어 w 가 등장한 빈도의 역수인 IDF는 아래의 수식 (2.4)으로 정의한다.

$$\text{IDF}(w, D) = \log \frac{|D|}{|d \in D : w \in d|} \quad (2.4)$$

결과적으로 TF-IDF는 수식(2.3),(2.4)의 곱인 아래의 수식 (2.5)으로 표현할 수 있다.

$$TF-IDF(w, d, D) = TF(w, d) \times IDF(w, D) \quad (2.5)$$

TF-IDF 알고리즘은 벡터 공간 모형을 활용하여 계산된 문서간의 상관 관계[7]의 가중치를 통해 대부분의 검색엔진이나 텍스트 마이닝 연구에 활용되고 있다.

2.2 관련 연구

2.2.1 사용자 상황 인지

스마트폰 센서로 수집 가능한 다종 데이터는 스마트폰 사용자의 물리적 움직임이나 주변 환경에 대한 정보를 담고 있어 이를 이용한 상황 인지 연구들에서 활발하게 사용되고 있다. 표2.1에서는 사용자의 상황을 인지하는 데에 센서 데이터들을 이용한 과거 연구들에 대해 정리하였다.

Table 2.1: 스마트폰 센서를 이용한 연구 사례

센서 종류	인지 정보	관련 연구들
가속도 센서	동작 인지	[8][9][10][11][12][13][14][15][16][17]
	수면 패턴 인지	[15][18]
	신체정보 추론	[19]
오디오 센서	동작 인지	[16][17]
	수면 패턴 인지	[15][18]
	사회적 상호작용	[15]
자이로스코프	동작 인지	[12][20]
	교통수단 인지	[21]
자기장 센서	동작 인지	[12][20][21]

사용자의 상황 인지에 있어서 가속도 센서 데이터의 활용이 그 빈도가 가장 높음을 알 수 있었다. 걷기, 뛰기, 계단 오르내리기 등의 동작 상태를 인지하는 경우들[8, 9, 10, 12, 13, 14, 15, 16, 17] 혹은 자동차, 자전거 등의 이용중인 교통수단을 인지하는 경우들[20] 등의 사용자의 동작 상태와 관련된 정보들을 인지하는 연구가 주로 이루어졌으며,

오디오 센서 데이터 역시 걷기, 서기, 앉기 등의 동작 관련 상황 인지에 사용되었고[16, 17], 사용자의 수면 패턴을 분석하는 연구에 사용되기도 했다[15, 18]. 또한 스마트폰 주변에서 일어나는 사용자의 대화 여부를 인지하고 이를 통해 사회적 상호작용 정도를 판단하는 연구가 진행되기도 하였다[15].

자이로스코프 센서 데이터를 통해서는 사용자의 동작이 걷는지, 계단을 오르내리고 있는지, 뛰는지 등을 인지하는 연구가 진행되었고[12, 20], 이용중인 교통 수단이 자전거인지, 버스인지, 자동차인지 등을 인지하는 연구가 진행되었다[21].

마지막으로 자기장 센서 데이터의 경우, 사용자가 정지 상태인지, 걷고 있는지, 뛰고 있는지 등의 동작을 인지하는 연구가 진행되기도 하였다[12, 20, 21].

2.2.2 사용자 특성 정보 추론

사용자로부터 발생한 데이터를 통해 특성 정보를 추론하는 연구는 웹 상에서의 활동을 통해 생성된 데이터를 기반으로 이루어져 왔다. 사용자의 작성 글 내용의 문체와 내용을 이용해서 성별과 연령대를 추론하거나[22, 23, 24, 25], 웹 브라우저 사용 기록을 통해 성별, 연령대, 인종 등의 정보를 추론[26, 27]하는 등의 연구들이 수행되어왔다. 이 때의 연구들은 주로 사용자의 생물학적 특성에 해당하는 정보를 추론하는 연구들이 주를 이루었다.

스마트폰의 보급이 일반화되고 그로부터 발생하는 데이터의 규모가 급증함에 따라, 이를 이용하는 사용자 특성 추론 연구가 많아지고 있다. 대표적으로, 노키아는 2013년에 다수의 피실험자들로부터 수집한 전화 및 메시지 기록, 연락처, GPS, 블루투스, 가속도 센서, 미디어 파일, 설치한 애플리케이션, 애플리케이션 사용 기록, 캘린더 기록 등의 스마트폰 데이터를 통해 성별, 연령대, 결혼 여부, 가족의 수 등의 사용자 특성을 추론하는 Mobile Data Challenge[28]를 주최하기도 하였다.

이 외에도 가속도 센서 데이터를 활용하여 성별, 신장, 체중 등의 신체정보를 추론[19]하거나 위치를 추론[29]하는 연구가 수행되었으며, 애플리케이션 사용 기록을 활용하여 성별, 연령을 추론[30]하는 연구가 진행되기도 하였다.

제 3 장 제안 기법

본 연구에서는 센서 데이터 기반의 사용자의 상황을 인지하는 모형의 입력값으로, 센서 데이터와 사용자 특성 정보를 함께 입력값으로 사용하는 기법을 제안한다. 사용자 특성 정보는 개인 정보 보호와 관련해서 민감할 수 있는 정보이기 때문에, 애플리케이션 설치 목록을 이용하여 추론하고 그 추론한 사용자 특성 정보를 스마트폰 다중 센서 데이터와 함께 상황 인지 모형의 입력값으로 사용하도록 한다.

3.1 전체 과정

제안 기법의 전체 과정은 아래의 그림 3.1으로 나타내었다.

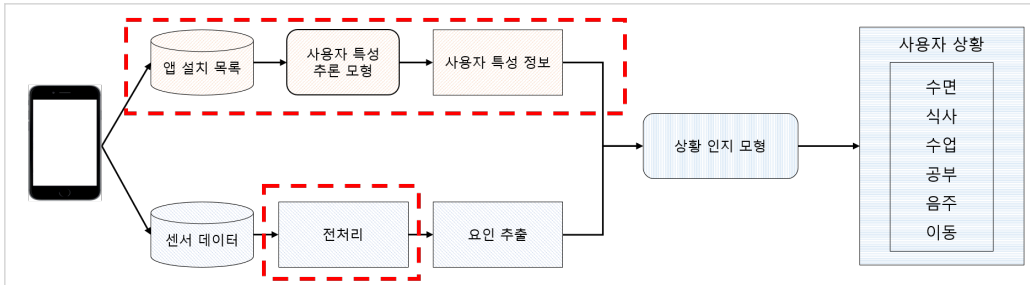


Figure 3.1: 제안 기법의 전체 과정

첫번째 단계로, 사용자 특성 정보를 직접적으로 획득하지 못한 경우에 한해서 필요한 특성 정보 항목들은 스냅샷 데이터인 애플리케이션 설치 목록을 통해 추론한다. 두번째로는, 수집한 인스턴스의 스마트폰 센서 데이터로부터 상황 인지 모형의 단서가 될 수 있는 요인 벡터들을 생성한다. 첫번째 단계의 경우 사용자 특성 정보 추론은 순간적으로

수행이 가능하기 때문에, 일정 주거나 특정 이벤트의 발생시마다 수행하거나, 두번째 단계인 상황 인지 모형에 필요한 요인 벡터를 생성할 때 동시에 수행하는 것도 충분히 가능하다.

상기 단계들에서 생성된 사용자 특성 정보 데이터와 요인 벡터 데이터에 대해 조인(join) 연산을 수행함으로써 이어 붙이고, 상황 인지 모형의 입력값으로 사용한다. 최종적으로 사용자 상황 인지 모형은 수면, 식사, 수업, 공부, 음주, 이동 여섯가지에 해당하는 사용자의 상황 컨텍스트를 분류한다.

3.2 데이터 전처리

3.2.1 데이터 수집 구간 동기화

스마트폰의 물리 센서들은 독립적으로 데이터를 수집하기 때문에, 단일한 애플리케이션에서 동일한 수집 주기를 설정하고 수집해도 서로 간의 타임스탬프에 미세한 차이가 발생하게 된다. 물리 센서의 동작을 주관하는 운영체제는 각 모듈을 각각의 독립된 스레드(thread) 단위로 제어하기 때문에, 각 모듈의 수집 시기와 빈도가 일정하지 않거나 특정 종류의 센서들이 작동을 하지 않은 구간이 발생하는 현상들이 나타나게 된다.




Figure 3.2: 모듈별 센서들 간의 수집 타임스탬프 차이의 예

그림 3.2는 가속도 센서와 조도 센서의 수집 예시로, 가속도 센서 데이터는 수집 빈도가 높고 고른 편인 것에 비해, 조도 센서의 경우는 센서 값이 변하는 시점에 한해서 데이터를 수집하기 때문에 수집 빈도나 횟수가 비교적 불규칙하고 그 수도 적은 모습을 볼 수 있다. 본 연구에서 상황 인지 모형의 입력값으로 사용한 센서 데이터는 단일 종류의 센서 데이터만을 사용하지 않았기 때문에, 활용하고자 하는 종류의 센서 데이터에서 인스턴스들의 타임스탬프를 활용하여 센서 종류 간의 오프셋 차이를 상쇄시켜, 동일한 타임스탬프와 동일한 빈도를 가지는 인스턴스로 합치는 전처리 과정이 필요하다. 이에 본 연구에서는 물리 센서 데이터에 적용할 수 있는 보간법(interpolation) 중 선형 보간법(linear interpolation)을 이용하여 인접한 데이터 값을 기준으로 기준 시점의 타임스탬프 값을 추론하여 센서 데이터들의 주기를 50Hz로 맞추는 전처리 과정을 수행한

결과를 활용하였다. 이 전처리 과정은 아래의 수식(3.1)으로 표현 할 수 있다.

$$f(x) = \frac{d_2}{d_1 + d_2} f(x_1) + \frac{d_1}{d_1 + d_2} f(x_2) \quad (3.1)$$

위 수식은 타임스탬프 x_1, x_2 에서의 각각의 센서 데이터 값인 $f(x_1), f(x_2)$ 로부터 50Hz의 타임스탬프에 해당하는 지점 x 에서의 데이터 값 $f(x)$ 을 추정하는 과정이며, 해당 과정을 거치는 예시를 아래의 그림 3.3으로 나타내었다.




Figure 3.3: 선형 보간법을 활용하여 타임스탬프 값의 주기를 맞추는 과정의 예

3.2.2 가속도 센서 데이터 보정

실험용 수집 데이터를 탐색하는 과정에서, 피실험자의 스마트폰이 정지상태이더라도 기기 별로 상이한 값이 수집될 수 있다는 사실과 동일 기기 내에서도 일정한 값이 수집되지 않을 수 있음을 확인하였다. 피실험자 별 정지 상태에서의 가속도 센서 측정량의 평균 및 표준 편차의 분포를 그림 3.4 에 나타내었다. 평균 값이 9.8과 차이가 크거나, 표준 편차가 0과 차이가 큰 값들이 존재함을 볼 수 있었다.




Figure 3.4: 피실험자 별 정지 상태에서의 가속도 센서 측정량의 평균 및 표준 편차




Figure 3.5: 95번 피실험자의 일자 별 정지 상태에서의 평균 가속도 센서 값의 변화

또한, 그림 3.5의 예시에서 처럼, 다수의 피실험자들의 실험 수행 일자 별로 정지 상태에서의 가속도 센서 측정 값의 평균값의 크기가 시간이 흐름에 따라 지속적으로 변화함을 확인할 수 있었다. 따라 가속도 크기를 보정하는 선형 방정식의 계수를 추정하고 이를 전체적으로 적용하는 방식은, 데이터 내에 크게 편향된 값이 일부 존재할 경우 추정한 계수 역시 편향될 가능성이 높기 때문에 일정 시간이 지난 후에는 부적절하게 작용할 수 있다. 따라서 본 연구에서는 계수의 범위에 대한 제약식을 추가한 선형 방정식을 근사하고, 센서 데이터의 변동성이 큰 경우에는 보정 계수를 주기적으로 갱신하여 새로운 선형 방정식으로 보정하는 방식을 채택하였다. 일정한 양의 보정을 위한 정지 상태의 인스턴스가 축적되었을 때마다 계수를 새로이 추정하고, 해당 시점 이후로는 계수가 갱신되기 전까지 이를 활용하였다.

정지 상태의 인스턴스들 중 일부를 샘플링해서 보정하는 방식보다, 주기적으로 보정 계수를 추정하는 방식이 더 큰 보정 효과를 낼 수 있음을 확인하였고, 95번 피실험자의 보정 결과를 그림 3.6에 나타내었다.




Figure 3.6: 95번 피실험자의 가속도 센서 데이터 보정 예시

3.2.3 오디오 센서 데이터 전처리

스마트폰 주변의 소리를 녹음하는 센서의 경우, 사용자의 사생활 침해로 이어질 수 있기 때문에 원본 데이터 대신 일정 시간 동안의 요인을 도출하도록 하고 이를 사용하였다. Mel-frequency cepstrum coefficients(MFCC), power spectral density(PSD), 도출한 여러 종류의 norm 값들 총 세 종류의 요인을 수집하도록 하였다.

원본 값이 아닌 요인 값을 수집했기 때문에 인스턴스 간의 타임스탬프 간격이 다른 종류의 센서 데이터들에 비해 길어진 결과, 앞서 소개한 수집 구간 동기화와 다른 방식의 전처리 방식을 사용하였다. 본 연구에서 사용한 데이터의 단일 인스턴스들의 주기는 50hz이기 때문에, 약 1hz 정도로 수집된 오디오 센서 데이터들에 대해 동일한 값들을 50hz 주기로 반복적으로 복제하여 삽입하는 전처리 방식을 수행하였다.

3.3 인지 모형

3.3.1 사용자 상황 인지

본 연구의 사용자 상황 인지 모형은 랜덤 포레스트 모형의 전체 트리 개수와 트리의 최대 계층 수 두 가지 매개변수의 조합을 통해 제일 좋은 성능을 보인 조합을 선택하였다. 매개변수의 조합으로, 전체 트리 개수는 20, 40, 60, 80, 100의 다섯 가지, 트리의 최대 계층 수는 5, 10, 15, 20의 네 가지 설정값으로 설정하였다. 사용한 센서 데이터의 종류는 가속도 센서, 선형 가속도 센서, 조도 센서, 오디오 센서의 네 가지를 사용하였고, 각 센서 데이터에서 추출한 요인들은 기존의 요인 추출 연구[31]를 참고하여 추출하였다.

3.3.2 사용자 특성 정보 추론

본 연구의 사용자 특성 정보 추론부는 [32], [33]의 연구에서 사용한 '애플리케이션 설치 목록', '애플리케이션 카테고리 비율', '애플리케이션 설명글 단어 TF-IDF'의 세 가지 요인 외에 추가적으로 '애플리케이션 설명글 Doc2Vec'을 활용하여, 총 네 가지 요인 벡터를 생성해 사용자 특성 정보 추론에 사용하였다.

단순 애플리케이션 목록의 경우, 특정 애플리케이션을 설치했는지의 여부를 하나의 요인으로 하는 벡터로 사용자가 특정 애플리케이션을 설치했으면 해당 요인 값은 1, 아니면 0을 갖도록 한다. 학습 데이터에 등장한 고유 애플리케이션 수가 요인 벡터의 차원이 되며, 사용자 한 명의 요인 값들의 총 합은 그 사용자가 설치한 애플리케이션 수와 같다.

애플리케이션 메타정보인 카테고리를 이용하여 사용자가 설치한 애플리케이션의 카테고리별 비율을 요인 벡터로 활용한다. 사용자가 설치한 특정 카테고리에 해당하는 애플리케이션 숫자를 해당 사용자가 설치한 애플리케이션의 총 개수로 나눈 값을 해당 요인 값으로 한다. 카테고리의 개수가 요인 벡터의 차원이 되며, 한 명의 사용자의 모

든 요인 값의 총 합은 1이 된다. 특정 사용자가 설치한 모든 애플리케이션의 설명글을 이어붙여 하나의 문서로 만들고, 해당 문서를 대상으로 단어를 추출하여 TF-IDF 값을 구하여 이를 해당 사용자를 표현하는 요인으로 활용하였다.

Ma, Qiang이 제안한 App2Vec[34]을 활용한 요인 벡터를 생성하여 사용자 특성 추론에 활용하였다. 학습 데이터에 등장한 모든 애플리케이션을 대상으로, 각 애플리케이션의 설명글 마다 Doc2Vec 기법을 적용하여 단어 벡터와 문서 벡터를 학습시켜 애플리케이션 벡터들을 생성하고, 특정 사용자가 설치한 애플리케이션들의 각 애플리케이션 벡터들의 평균을 요인으로 사용한다.

제 4 장 실험 및 결과

4.1 실험 데이터

4.1.1 데이터 수집용 애플리케이션

본 연구에서 제안한 사용자 상황 인지 모형의 성능을 평가하기 위한 데이터를 수집하기 위해, 안드로이드 애플리케이션인 SCDC(smart campus data collection)을 개발하고, 피실험자들의 스마트폰에 배포하였다. 안드로이드는 Google에서 개발한 스마트 기기용 운영체제로, 애플리케이션의 개발과 배포가 자유롭고, 본 연구에서 사용한 센서 데이터와 스냅샷 데이터의 경우, 별도의 권한 요구 없이 수집할 수 있는 것이 그 특징이다. 아래의 그림4.1은 SCDC의 메인 인터페이스 화면이다.



Figure 4.1: SCDC의 메인 인터페이스

SCDC로 실험을 수행 중인 상황에 한해서만 데이터를 수집하도록 구현하였으며, SCDC가 백그라운드 모드에 진입하더라도 안정적으로 데이터를 수집하도록 안드로이드 서비스 프로세스 구동 기능을 구성하였다. 피실험자의 스마트폰으로부터 수집한 데이터를 피실험자가 자유로이 업로드할 수 있도록, 데이터 수집용 웹 서버 애플리케이션을 Python언어의 Django패키지에 MySQL 데이터베이스를 구축하여 활용하였다.

본 연구에서 활용한 컨텍스트 별 데이터 수집 주기와 모달리티 별 수집 빈도를 아래의 표4.1, 표4.2에 정리하였다.

Table 4.1: 수집 상황 컨텍스트 별 데이터 수집 주기

상황 컨텍스트	수집 주기
식사, 수업, 공부, 음주, 이동	40초 수집, 80초 휴식 (120초 주기)
수면	40초 수집, 560초 휴식 (600초 주기)

Table 4.2: 모달리티 별 데이터 수집 간격

모달리티	수집 간격
애플리케이션	수면 상황 수집 1시간 경과 후 1회
조도 센서	주기 시작 시 1회, 이후는 값이 변경 될 때
오디오 센서	주기 내 1초당 1회
가속도 센서 선형 가속도 센서 자기장 센서 자이로스코프 센서 회전 벡터 센서	주기 내 0.02초당 1회

4.1.2 데이터 수집 실험

실험에 앞서, 피실험자들의 사용자 특성 정보를 설문조사를 통해 입력받아 사용자 특성 정보 데이터를 구축하였고, 특성별 분포를 아래 표4.3에 정리하였다.

Table 4.3: 사용자 특성 정보 항목별 분포

항목	분포	총 인원
성별	남자 56명 여자 44명	100
연령	평균 23.3세, 표준편차 2.3세	100
신장	평균 170cm, 표준편차 9.1cm	100
체중	평균 63kg, 표준편차 14.4kg	100
종교	무교 71명 개신교 13명 천주교 8명 불교 8명	100
연애상태	비연애중 55명 연애중 45명	100
거주형태	자택 39명 임대주택 30명 미응답 31명	100
동거여부	동거 75명 비동거 21명 미응답 4명	100
단과대학	공과대학 22명 사회과학대학 14명 그 외 64명	100
수입수준	월 50만원 미만 39명 월 50만 100만원 52명 월 100만 300만원 9명	100
지출수준	월 50만원 미만 42명 월 50만 100만원 54명 월 100만 300만원 4명	100
이수학기	평균 5학기, 표준편차 2.8학기 미응답 30명	100

사용자 특성 정보로는 성별, 연령, 신장, 체중, 종교, 연애상태, 거주형태, 동거여부, 수입수준, 지출수준으로 열 가지 항목과, 피실험자들의 구성이 모두 대학생과 대학원생들임을 고려하여 이수학기, 단과대학의 두 가지 항목으로 총 열 두 가지의 사용자 특성 정보를 수집하였다. 총 100명의 피실험자들이 데이터 수집 실험에 참여하였고, 스마트폰을 피실험자 본인으로부터 멀리 떨어뜨려 놓은 채 방치하는 경우를 제외한 일상 생활의 모든 상황에서 실험을 수행하도록 하였다. 기기의 위치에 대한 제약은 두지 않도록 하였으며, 서비스 프로세스로 데이터 수집이 가능하도록 구현하였기 때문에 수집 실험 중에 스마트폰의 사용은 평소처럼 사용할 수 있도록 하였다. '이동' 상황을 제외한 상황 컨텍스트들은 비이동 상황에서만 수집하도록 하는 제약 외에는, 통제가 거의 없는 실생활에 가까운 환경의 데이터 수집 실험을 하였다.

4.2 실험 설계

먼저 피실험자들로부터 수집한 스마트폰 센서 데이터를 이용해 요인 벡터들을 생성하고 이를 이용해 사용자의 상황을 인지하는 실험을 수행하였다. 이때, 인지 대상이 되는 상황은 수면, 식사, 수업, 공부, 음주, 이동 여섯 추론 모형은 랜덤 포레스트 분류기를 사용하였다.

사용자 특성 정보가 상황 인지의 향상에 효과가 있는지 살펴보기 위해, 피실험자들의 실제 사용자 특성 정보를 함께 사용한 성능과 센서 데이터만을 사용한 성능을 비교하였다.

다음으로는 구현한 사용자 특성 정보 추론부의 성능을 확인하기 위해 스마트폰 애플리케이션 설치 목록을 이용해 세 종류의 요인 벡터를 생성하고, 로지스틱 회귀와 선형 회귀를 학습 알고리즘으로 사용하여 사용자 특성 정보를 추론하였다. 사용자 특성 정보는 성별, 종교, 거주형태, 동거여부, 수입수준, 지출수준, 연애상태, 단과대학 여덟 가지의 범주형 항목과 연령, 신장, 체중, 이수학기 네 가지의 수치형 항목을 추론하는 실험을 수행하였다.

최종적으로는, 사용자 특성 정보 추론부의 결과값인 사용자 특성 정보를 센서 데이터와 함께 사용했을 때의 성능과 센서 데이터만을 사용한 성능의 차이를 살펴보았다.

4.3 실험 환경 및 평가 지표

4.3.1 실험 환경

본 연구의 실험은 Python 언어로 구현하고 수행하였다. 상황 인지 모형의 경우, scikit-learn 패키지를 이용하여 구현하였다. 사용자 특성 추론부의 경우는 BeautifulSoup 패키지를 이용하여 애플리케이션 메타 데이터를 크롤링하고, 크롤링한 애플리케이션 메타 데이터의 자연어 처리를 위해 한글은 KoNLPy 패키지를, 영어는 Natural Language Toolkit 패키지를 사용하였다. 메타 데이터로 사용자 임베딩 요인 벡터를 생성하기 위해 Google에서 지원하는 TensorFlow 프레임워크를 사용하였고, 특성 정보 추론을 위한 회귀 모형 구현은 scikit-learn 패키지를 이용하였다.

본 연구에서 수행한 실험들은 모두 계층적 무작위 10-등분 교차타당화 방법을 100회 반복하는 방식으로 수행하였고, 반복한 실험 결과의 평균을 최종 성능으로 사용하였다

4.3.2 평가 지표

상황 인지 모형의 성능은 오분류율(error rate)을 평가하였다. 사용자 특성 정보 추론의 성능으로는 성별, 연애상태, 거주형태, 동거여부, 수입수준, 지출수준, 종교, 단과대학의 8가지 범주형 항목은 오분류율로 평가하였고, 연령, 신장, 체중, 이수학기의 4가지 수치형 항목은 평균 제곱근 오차(Root Mean Square Error, RMSE)로 평가하였다. 오분류율은 수식 (4.1) 같이 정의하고, 평균 제곱근 오차는 수식 (4.2) 와 같이 정의한다.

상황 인지 모형의 경우, 수식 (4.1) 에서 N 은 인지 대상 인스턴스의 전체 숫자, \hat{y}_i 은 인지 결과 값을, y_i 는 실제 값을 나타낸다. 사용자 특성 정보 추론부에서의 경우, (4.1), (4.2) 에서 N 은 특성 추론의 대상이 되는 사용자의 숫자, \hat{y}_i 은 추론 값, y_i 는 실제 값을 나타낸다.

$$1_{\hat{y}_i \neq y_i} = \begin{cases} 1, & \text{if } \hat{y}_i \neq y_i \\ 0, & \text{otherwise.} \end{cases} \quad (4.1)$$

$$\text{error rate} = \frac{1}{N} \sum_{i=1}^N 1_{\hat{y}_i \neq y_i}$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (4.2)$$

4.4 실험 결과

4.4.1 사용자 상황 인지 모형 최적 매개변수

사용자 상황 인지 모형의 최적 성능을 탐색하기 위해, 다중 센서 데이터들의 조합들과 기존 연구[35]의 랜덤포레스트 모형을 기반으로 한 인지 모형의 매개변수들의 조합들 사이의 성능을 실험하였다. 인지 모형은 그 결과, 최적의 매개변수 조합은 결정 트리의 개수는 100으로, 트리의 최대 계층 수는 15로 설정한 경우였으며 센서 데이터의 조합들 중에서는 가속도 센서 데이터와 오디오 센서 데이터의 두 종류의 센서 데이터를 입력 값으로 사용한 경우였다. 이후의 실험 과정에서는 해당 조합의 매개변수를 적용하여 실험을 수행하였다.

57종의 다중 클래스들 중, 성능이 좋은 순으로 10개의 클래스를 정리한 것은 아래의 표4.4과 같다.

Table 4.4: 인지 성능 상위 10개의 사용자 상황 클래스

순위	상황 클래스	오분류율
1	수면, 이동	0.07
2	공부, 이동	0.09
3	수업, 이동	0.10
4	식사, 이동	0.12
5	수면, 공부, 이동	0.12
6	수면, 음주, 이동	0.20
7	수면, 음주, 이동	0.22
8	수면, 수업	0.23
9	수면, 공부, 이동	0.25
10	수면, 음주	0.26

여섯 종류의 상황 컨텍스트들 중, 2개 이상의 상황으로 만들 수 있는 모든 조합을 클래스로 상황 인지 모형의 성능 실험을 수행하였고, 성능은 오분류율로 측정하였다. 각

클래스들 모두 계층적 무작위 10-등분 교차타당화 방법을 100회 반복한 결과들의 평균을 해당 클래스의 최종 성능으로 사용하였다.

표4.4의 결과를 볼 때, 상황 클래스들 중 제일 비중이 높은 상황은 이동과 수면 상황이었다. 이동 상황을 제외한 나머지 상황들은 모두 스마트폰이 정지 상태에서 일어나는 상황들이기 때문에 가속도 센서 데이터의 구분력이 크게 작용한 것으로 보이고, 수면의 경우는 주변의 소리가 거의 없는 조용한 상황이기 때문에 오디오 센서 데이터의 구분력이 크게 작용한 것으로 판단된다.

4.4.2 사용자 특성 정보 적용 여부

사용자 특성 정보 추론부를 센서 데이터와 함께 사용했을 때 실제로 상황 인지 모형의 성능에 향상이 있는지의 여부를 보기 위해, 피실험자들로부터 직접 전달받은 실제 사용자 특성 정보를 적용한 상황 인지 모형의 성능 변화를 관찰하였다.




Figure 4.2: 사용자 특성 정보의 오류율에 따른 상황 인지 모형의 정확도

위의 그림 4.2은 12종의 사용자 특성 정보들에, 스마트폰 화면을 켜고 끈 기록을 통해 일 평균 스마트폰 사용 시간 항목을 더한 13종의 사용자 특성 정보들을 적용하여 사용자 특성 정보를 적용했을 때의 사용자 상황 인지 모형의 성능 변화를 관찰한 결과이다. 여기서, 적용한 사용자 특성 정보의 정확도에 따른 인지 성능 변화를 관찰하기 위해 57종의 상황 클래스 별로 100회의 인지 수행 평균 성능 수치를 성능으로 사용하였고, 사용자 특성 정보를 적용한 경우 역시 57종의 각 모든 상황 클래스 별로 100회의 인지 수행 평균 성능 수치를 사용하였다. 사용자 특성 정보의 오류는 100회마다 정해진 비율에 따라 무작위로 첨가하였으며, 오류율은 1%에서 27%까지 2% 단위로 13가지의 경우를 설정하여 실험을 수행하였다. 사용자 특성 정보 적용 여부에 따른 사용자 상황

인지 성능의 변화를 관찰해본 결과, 사용자 특성 정보의 오류율이 낮아질수록 상황 인지 모형의 성능 향상 정도가 높아지는 경향이 있음을 발견하였고 사용자 특성 정보가 정확할수록, 상황 인지 모형의 성능이 향상됨을 알 수 있었다.

다음으로 기존 연구의 인지 모형[35]을 기반으로 최적 매개변수를 탐색하여 적용한 인지 모형에 사용자 특성 정보를 추가했을 때, 성능 향상도가 높은 상황 컨텍스트 클래스를 탐색해보았으며, 성능 향상도가 높은 상위 10개의 클래스들을 표4.5에 정리하였다.

Table 4.5: 인지 성능 향상도 상위 10종의 사용자 상황 클래스

순위	상황 클래스	정확도 향상 비율(%)
1	식사, 공부	12.56
2	수면, 식사, 수업, 공부, 음주	10.01
3	식사, 수업, 공부	9.69
4	식사, 공부, 음주	9.68
5	식사, 수업, 공부, 음주	8.47
6	수면, 식사, 수업, 공부	6.76
7	수면, 식사, 공부, 음주	6.54
8	식사, 수업, 공부, 이동	6.17
9	수업, 공부, 음주	5.70
10	수면, 식사, 공부	5.50

사용자 특성 정보를 적용할 경우, 주로 정지 상태의 상황으로 이루어진 클래스들에서 상황 인지의 정확도 향상이 발생함을 볼 수 있었다. 상위 10순위 안에는 들지 않았지만, 6종의 모든 상황 클래스 역시 4.90%의 성능 향상이 있었고, 총 57종의 조합들 중 47종의 클래스에서 상황 인지의 정확도가 향상 되었다.

사용자 특성 정보의 개별적인 영향도를 살펴보기 위한 단계로는, 사용자 특성 정보를 1종씩만 적용했을 경우와 1종을 뺀 11종씩 적용했을 경우의 상황 인지 모형의 성능의 변화를 관찰하였다. 우선 사용자 특성 정보를 1종씩만 적용한 결과는 그림4.3에

나타내었다.




Figure 4.3: 적용한 사용자 특성 별 상황 인지 모형의 성능 향상도

그림4.3의 결과를 통해 상황 인지 모형의 상승에 기여도가 클 것으로 예상되는 체중, 종교, 거주형태를 선택하기로 하였다. 그 다음으로, 상승 기여도가 낮은 사용자 특성 정보를 알아보기 위해 1종씩 제외한 실험의 결과를 아래의 그림4.4에 나타내었다.




Figure 4.4: 제외한 사용자 특성 별 상황 인지 모형의 성능 향상도

그림4.4의 결과를 통해 종교, 신장, 동거여부, 휴대폰사용시간의 네 가지 항목을 선택하였다. 이후의 사용자 특성 정보 적용 실험은 체중, 신장, 종교, 거주형태, 동거여부, 휴대폰사용시간의 6종을 적용하였다.

4.4.3 사용자 특성 정보 추론 실험

앞서 제안한 네 가지 요인 벡터들을 이용해 체중, 신장, 종교, 거주형태, 동거여부의 5종류의 사용자 특성 정보를 추론하는 실험을 진행하였다. 휴대폰사용시간은 스크린을 끄고 킨 타임스탬프를 통해 별도의 추론 과정 없이 획득할 수 있는 정보로 간주하여 추론 실험의 대상에서 제외하였다. 각 사용자 특성 항목 별로 네 가지 요인 벡터들을 이용한 추론 결과들을 앙상블한 성능도 함께 측정하여, 각 특성 정보 별로 가장 좋은 성능을 보인 요인 벡터들을 표 4.6에 정리하였다.

Table 4.6: 사용자 특성 정보 추론부의 최종 성능 도출

특성 정보	요인 벡터	성능
신장	앙상블	7.49cm (RMSE)
체중	앙상블	12.60kg (RMSE)
종교	카테고리 비율	0.28 (error rate)
거주형태	설명글 Doc2Vec	0.30 (error rate)
동거여부	앙상블	0.20 (error rate)

네 가지 요인 벡터를 모두 이용하여 앙상블 했을 때 좋은 성능을 달성한 경우가 가장 많았으며, 종교의 경우는 애플리케이션 설치 카테고리 비율을 이용했을 때, 거주형태의 경우는 애플리케이션 설명글 Doc2Vec을 이용했을 때 가장 좋은 성능을 보였다.

4.4.4 실제 추론한 사용자 특성 정보를 적용한 상황 인지 모형의 성능

앞서 수행한 과정들을 통해 선정한 항목의 사용자 특성 정보를 실제 추론한 값을 적용하여 상황 인지 모형의 성능을 측정하는 실험을 수행하였다.

선정한 사용자 특성 정보들의 추론값을 적용했을 때, 사용자 상황 인지 모형의 성능 향상도의 상위 10개 항목은 표4.7에 정리하였다.

Table 4.7: 인지 성능 향상도 상위 10종의 사용자 상황 클래스

순위	상황 클래스	정확도 향상 비율(%)
1	식사, 공부, 음주	10.36
2	식사, 수업, 공부, 음주	10.18
3	식사, 공부	5.98
4	식사, 수업, 공부	5.88
5	수업, 공부, 음주	5.33
6	수업, 음주	4.44
7	식사, 음주	4.33
8	수업, 공부	4.33
9	식사, 수업	4.32
10	식사, 수업, 음주	4.32

표4.7의 결과를 통해, 선정한 항목의 사용자 특성 정보가 주로 이동 상황이 끼이지 않은 정적 컨텍스트 상황의 인지 성능 향상에 그 효과가 있음을 볼 수 있다. 상위 10종의 클래스에 속한 사용자의 상황 컨텍스트는 식사, 수업, 공부, 음주의 네 가지 상황으로, 물리 센서 데이터만을 사용하여 상황 인지를 수행할 경우 하위에 속하는 순위의 클래스들이다. 실제 추론한 사용자 특성 정보를 적용한 상황 인지 모형의 컨텍스트 클래스별 분포는 그림4.5에 보이는 분포를 보였다.

실제 사용자 특성 정보를 적용한 실험과 마찬가지로, 57종의 클래스들 중 47종의 상황




Figure 4.5: 사용자 상황 클래스별 성능 향상도 분포

클래스 인지에서 성능 향상을 보였으며, 5% 이상의 향상도를 보인 클래스는 5종이었고, 상위 항목을 차지하는 클래스들은 앞서 센서 데이터만을 사용했을 때 상위에 속해있던 이동이나 수면 상황의 항목이 없음을 볼 수 있었다.

제 5 장 결론

5.1 요약 및 연구 의의

본 연구에서는 사용자의 특성 정보를 활용하여 고수준 컨텍스트인 수면, 식사, 수업, 공부, 음주, 이동의 상황을 인식하는 물리 센서 데이터 기반의 인지 모형의 성능을 향상시키는 방법을 제안하였다. 특히나, 사용자 특성 정보는 사생활 침해 우려가 있을 수 있는 민감한 정보들이기 때문에 스냅샷 데이터인 스마트폰 애플리케이션 설치 목록을 활용해 사용자 특성 정보를 추론하고 이를 사용자 상황 인지 모형에 적용하는 두 단계로 이루어진 기법의 효용성을 검증하였다.

다중 센서 데이터의 통합을 위해, 독립적인 모듈로 이루어진 스마트폰 상의 물리 센서들로부터 각각 수집된 데이터를 하나의 입력값으로 통합하는 선형 보간법 과정을 거쳐 데이터 수집 구간을 동기화 하였다. 또한, 기존의 보정 방식보다 편향성을 줄이는 효과를 보인 주기적 갱신형 보정 방식을 제안하고 이를 가속도 센서 데이터에 적용하는 과정을 거쳤다.

전처리 과정을 거친 물리 센서 데이터를 활용하여 랜덤 포레스트 모형을 사용자 상황 인지의 성능을 최적화 하기 위한 매개변수 탐색을 하였고 수집한 사용자 특성 정보들 각 항목이 사용자 상황 인지 성능에 미치는 영향을 분석하여, 상황 인지 모형의 성능을 향상시키는 사용자 특성 정보의 클래스들을 탐색하였다.

스냅샷 데이터를 활용한 사용자 특성 추론 방식에 애플리케이션 설치 목록을 이용해 생성한 요인 벡터들로부터 사용자 특성을 추론하였고, 이를 물리 센서 데이터에 적용하여 기존 방식의 사용자 상황 인지 모형의 성능보다 평균적으로 13%의 향상된

성능을 도출할 수 있었다.

사용자 특성 추론에 활용한 스냅샷 데이터는 수집 시 사용자에게 획득해야 하는 별도의 권한이 필요 없으며 순간적으로 획득이 가능하기 때문에, 물리 센서 데이터를 활용하는 모형 뿐 아니라 사용자 특성 정보가 도움이 될 수 있는 다른 영역에 활용할 수 있는 가능성이 높다.

일련의 과정들을 통해 대부분의 사용자 특성 정보는 해당 사용자의 상황을 추론하는데에 효과가 있음을 알 수 있었고, 이진 분류 모형을 구성할 경우에는 모형 별로 최적화 과정을 거쳐 사용자의 상황을 추론하는 모형의 추가적인 향상의 가능성도 존재한다는 점을 알 수 있었다.

5.2 향후 연구

본 연구에서는 다중 물리 센서 데이터를 통합하여 동일한 인스턴스의 입력값으로 변환하는 데이터 전처리 기법을 제안하였다. 동일한 타임스탬프로 변환하는 과정에서 사람이 느끼기 힘든 극미한 차이일지라도 타임스탬프의 오차 발생은 불가피하다. 이러한 오차로 인해, 입력값으로 쓰인 통합된 물리 센서 데이터들은 온전히 오류가 없는 데이터라고 볼 수 없다. 향후 오차를 최소화할 수 있는 데이터 수집 방식과 좀 더 정교한 전처리 방식을 연구하여, 모형의 성능 이전에 데이터의 무결성을 향상 시킬 수 있는 기법을 마련할 것이다. 또한, 본 연구에서 상황 인지 모형으로 활용한 랜덤 포레스트 모형은 근래에 각광받고 있는 심층 학습 기법의 모형들에 비해 학습 소요 시간이나 추론에 필요한 비용이 비교적 적은 편이기에, 실제 서비스에 많이 활용되고 있다. 그러나, 최근에는 인공 신경망의 입력값 차원을 줄이는 기법을 통해 스마트폰 사양에서도 연산량을 줄이면서 준수한 성능을 보장하는 심층 학습 기법의 연구도 이루어지고 있고, 휴대용 스마트기기들의 평균 사양들도 급속도로 올라가고 있는 추세이기 때문에 뛰어난 성능의 심층 학습 기법의 모형들도 휴대용 스마트기기 상에서 수행하는 것이 가능해질 것이다. 따라서 본 연구를 심층 학습 기법에 적용하는 연구를 수행할 예정이다.

그리고 사용자 특성 추론 역시나 스마트폰 애플리케이션 목록의 텍스트 정보만을 활용했으나, 애플리케이션의 메타정보에는 사용자의 평가 정보나 애플리케이션 사용 스크린샷 등의 추가적으로 활용할 수 있는 정보들이 있다. 이러한 추가적인 데이터를 사용하여 보다 향상된 수준의 사용자의 특성 정보를 추론할 수 있는 기법을 제안할 수 있는 연구도 수행할 예정이다.

참고 문헌

- [1] Quoc Le and Tomas Mikolov. Distributed representations of sentences and documents. In *International Conference on Machine Learning*, pages 1188–1196, 2014.
- [2] Tomas Mikolov, Ilya Sutskever, Kai Chen, Greg S Corrado, and Jeff Dean. Distributed representations of words and phrases and their compositionality. In *Advances in neural information processing systems*, pages 3111–3119, 2013.
- [3] Wei-Ti Kuo, Yu-Chun Wang, Richard Tzong-Han Tsai, and Jane Yung-jen Hsu. Contextual restaurant recommendation utilizing implicit feedback. In *Wireless and Optical Communication Conference (WOCC), 2015 24th*, pages 170–174. IEEE, 2015.
- [4] Leo Breiman. Random forests. *Machine learning*, 45(1):5–32, 2001.
- [5] Antonio Criminisi, Jamie Shotton, Duncan Robertson, and Ender Konukoglu. Regression forests for efficient anatomy detection and localization in ct studies. In *International MICCAI Workshop on Medical Computer Vision*, pages 106–117. Springer, 2010.
- [6] Jamie Shotton, Andrew Fitzgibbon, Mat Cook, Toby Sharp, Mark Finocchio, Richard Moore, Alex Kipman, and Andrew Blake. Real-time human pose recog-

- nition in parts from single depth images. In *Computer Vision and Pattern Recognition (CVPR), 2011 IEEE Conference on*, pages 1297–1304. Ieee, 2011.
- [7] Ray R Larson. Introduction to information retrieval. *Journal of the American Society for Information Science and Technology*, 61(4):852–853, 2010.
- [8] Sian Lun Lau, Immanuel König, Klaus David, Baback Parandian, Christine Carus-Düssel, and Martin Schultz. Supporting patient monitoring using activity recognition with a smartphone. In *Wireless communication systems (ISWCS), 2010 7th international symposium on*, pages 810–814. IEEE, 2010.
- [9] Amit Pande, Yunze Zeng, Aveek K Das, Prasant Mohapatra, Sheridan Miyamoto, Edmund Seto, Erik K Henricson, and Jay J Han. Energy expenditure estimation with smartphone body sensors. In *Proceedings of the 8th International Conference on Body Area Networks*, pages 8–14. ICST (Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering), 2013.
- [10] Joao Prudêncio, Ana Aguiar, and Daniel Lucani. Physical activity recognition from smartphone embedded sensors. In *Iberian Conference on Pattern Recognition and Image Analysis*, pages 863–872. Springer, 2013.
- [11] Sian Lun Lau and Klaus David. Movement recognition using the accelerometer in smartphones. In *Future Network and Mobile Summit, 2010*, pages 1–9. IEEE, 2010.

- [12] Yi He and Ye Li. Physical activity recognition utilizing the built-in kinematic sensors of a smartphone. *International Journal of Distributed Sensor Networks*, 9(4):481580, 2013.
- [13] Jennifer R Kwapisz, Gary M Weiss, and Samuel A Moore. Activity recognition using cell phone accelerometers. *ACM SigKDD Explorations Newsletter*, 12(2):74–82, 2011.
- [14] Young-Seol Lee and Sung-Bae Cho. Activity recognition with android phone using mixture-of-experts co-trained with labeled and unlabeled data. *Neuro-computing*, 126:106–115, 2014.
- [15] Nicholas D Lane, Mashfiqui Mohammad, Mu Lin, Xiaochao Yang, Hong Lu, Shahid Ali, Afsaneh Doryab, Ethan Berke, Tanzeem Choudhury, and Andrew Campbell. Bewell: A smartphone application to monitor, model and promote wellbeing. In *5th international ICST conference on pervasive computing technologies for healthcare*, pages 23–26, 2011.
- [16] Pekka Siirtola and Juha Röning. Recognizing human activities user-independently on smartphones based on accelerometer data. *IJIMAI*, 1(5):38–45, 2012.
- [17] Gabriel Filios, Sotiris Nikoletseas, Christina Pavlopoulou, Maria Rapti, and Sébastien Ziegler. Hierarchical algorithm for daily activity recognition via smartphone sensors. In *Internet of Things (WF-IoT), 2015 IEEE 2nd World Forum on*, pages 381–386. IEEE, 2015.

- [18] Jun-Ki Min, Afsaneh Doryab, Jason Wiese, Shahriyar Amini, John Zimmerman, and Jason I Hong. Toss’n’turn: smartphone as sleep and sleep quality detector. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, pages 477–486. ACM, 2014.
- [19] Gary M Weiss and Jeffrey W Lockhart. Identifying user traits by mining smart phone accelerometer data. In *Proceedings of the Fifth International Workshop on Knowledge Discovery from Sensor Data*, pages 61–69. ACM, 2011.
- [20] Attila Reiss, Gustaf Hendeby, and Didier Stricker. A competitive approach for human activity recognition on smartphones. In *European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning (ESANN 2013), 24-26 April, Bruges, Belgium*, pages 455–460. ESANN, 2013.
- [21] Arash Jahangiri and Hesham A Rakha. Applying machine learning techniques to transportation mode recognition using mobile phone sensor data. *IEEE transactions on intelligent transportation systems*, 16(5):2406–2417, 2015.
- [22] Jonathan Schler, Moshe Koppel, Shlomo Argamon, and James W Pennebaker. Effects of age and gender on blogging. In *AAAI spring symposium: Computational approaches to analyzing weblogs*, volume 6, pages 199–205, 2006.
- [23] Dong Nguyen, Noah A Smith, and Carolyn P Rosé. Author age prediction from text using linear regression. In *Proceedings of the 5th ACL-HLT Workshop on Language Technology for Cultural Heritage, Social Sciences, and Humanities*, pages 115–123. Association for Computational Linguistics, 2011.

- [24] Na Cheng, Rajarathnam Chandramouli, and KP Subbalakshmi. Author gender identification from text. *Digital Investigation*, 8(1):78–88, 2011.
- [25] William Deitrick, Zachary Miller, Benjamin Valyou, Brian Dickinson, Timothy Munson, and Wei Hu. Author gender prediction in an email stream using neural networks. *Journal of Intelligent Learning Systems and Applications*, 4(03):169, 2012.
- [26] Jian Hu, Hua-Jun Zeng, Hua Li, Cheng Niu, and Zheng Chen. Demographic prediction based on user’s browsing behavior. In *Proceedings of the 16th international conference on World Wide Web*, pages 151–160. ACM, 2007.
- [27] Sharad Goel, Jake M Hofman, and M Irmak Sirer. Who does what on the web: A large-scale study of browsing behavior. In *ICWSM*, 2012.
- [28] Juha K Laurila, Daniel Gatica-Perez, Imad Aad, Jan Blom, Olivier Bornet, Trinh Minh Tri Do, Olivier Dousse, Julien Eberle, and Markus Miettinen. From big smartphone data to worldwide research: The mobile data challenge. *Pervasive and Mobile Computing*, 9(6):752–771, 2013.
- [29] Jun Han, Emmanuel Owusu, Le T Nguyen, Adrian Perrig, and Joy Zhang. Accomplice: Location inference using accelerometers on smartphones. In *Communication Systems and Networks (COMSNETS), 2012 Fourth International Conference on*, pages 1–9. IEEE, 2012.
- [30] Yilei Wang, Yuanyang Tang, Jun Ma, and Zhen Qin. Gender prediction based on data streams of smartphone applications. In *International Conference on Big Data Computing and Communications*, pages 115–125. Springer, 2015.

- [31] Yonatan Vaizman, Katherine Ellis, and Gert Lanckriet. Recognizing detailed human context in the wild from smartphones and smartwatches. *IEEE Pervasive Computing*, 16(4):62–74, 2017.
- [32] Suranga Seneviratne, Aruna Seneviratne, Prasant Mohapatra, and Anirban Mahanti. Your installed apps reveal your gender and more! In *Proceedings of the ACM MobiCom workshop on Security and privacy in mobile environments*, pages 1–6. ACM, 2014.
- [33] Eric Malmi and Ingmar Weber. You are what apps you use: Demographic prediction based on user’s apps. In *ICWSM*, pages 635–638, 2016.
- [34] Qiang Ma, S Muthukrishnan, and Wil Simpson. App2vec: Vector modeling of mobile apps and applications. In *Advances in Social Networks Analysis and Mining (ASONAM), 2016 IEEE/ACM International Conference on*, pages 599–606. IEEE, 2016.
- [35] Anzah H Niazi, Delaram Yazdansepa, Jennifer L Gay, Frederick W Maier, Lakshmish Ramaswamy, Khaled Rasheed, and Matthew P Buman. A hierarchical meta-classifier for human activity recognition. In *Machine Learning and Applications (ICMLA), 2016 15th IEEE International Conference on*, pages 81–86. IEEE, 2016.
- [36] Gobinda G Chowdhury. *Introduction to modern information retrieval*. Facet publishing, 2010.

- [37] Jonathan Lester, Tanzeem Choudhury, and Gaetano Borriello. A practical approach to recognizing physical activities. In *International conference on pervasive computing*, pages 1–16. Springer, 2006.
- [38] Hyang-Mi Yoo, Jae-Won Suh, Eun-Jong Cha, and Hyeon-Deok Bae. Walking number detection algorithm using a 3-axial accelerometer sensor and activity monitoring. *The Journal of the Korea Contents Association*, 8(8):253–260, 2008.
- [39] André C Santos, Luís Tarrataca, Joao MP Cardoso, Diogo R Ferreira, Pedro C Diniz, and Paulo Chainho. Context inference for mobile applications in the upcase project. In *International Conference on Mobile Wireless Middleware, Operating Systems, and Applications*, pages 352–365. Springer, 2009.
- [40] Kyung Cha and SunDong Yeo. Smart phone application development for aware of unexpected conditions using accelerometer sensors. *Journal of the Korea Industrial Information Systems Research*, 17(5):1–8, 2012.
- [41] Kazushi Ikeda, Gen Hattori, Chihiro Ono, Hideki Asoh, and Teruo Higashino. Twitter user profiling based on text and community mining for market analysis. *Knowledge-Based Systems*, 51:35–47, 2013.
- [42] Ling Bao and Stephen S Intille. Activity recognition from user-annotated acceleration data. In *International Conference on Pervasive Computing*, pages 1–17. Springer, 2004.

Abstract

Enhancement of high-level context recognition performance based on smartphone data using user information

Jaehong Lee

Department of Industrial Engineering

The Graduate School

Seoul National University

The use of smartphone, which is personalization devices, has become universal, and as various types of services using appear, the demand for customized services according to the user's situation is increasing. In addition to existing cellular phone functions such as voice call and text message, smartphone plays a role as a personal computer capable of utilizing applications that utilizing data communication and multi-modal sensor data. Since many smartphone users carry smartphone most of the time in daily life, research using data generated from smartphone to recognize situation of user and infer user information has been variously promoted. A study on recognition of high-level context that may change its meaning depending on social and cultural differences, compared with research on recognition of low-level context according to physical exercise using sensor data. The recognition of high-level

context has degree of dependence of physical sensor data is relatively low, and the degree of difficulty is also high. The higher accuracy of the high-level context recognition, the more diversified and customized services would be available for various situations. Therefore, in this research, user information is used for the user situation recognition model of smartphone sensor data, based on the fact that the distribution of the sensor data changes according to the characteristics of the user for the improvement of recognition model's accuracy.

The method proposed in this research consists of two stages. As the first step, snapshot data that can be acquired instantaneously is used, so user information can be inferred immediately. In the second stage, the user information obtained at the first stage is merged with the sensor data to be used as input value of user's situation recognition model.

In the user information inference model, learning is performed by using feature vectors generated from the list of smartphone applications, and user information is inferred. The situation recognition model uses the accelerometer data and audio sensor data. And it uses the random forest classification model which is a kind of ensemble learning method to make a total of six situations of sleeping, having a meal, in class, studying, drinking and moving.

Keywords: recognition of user situation, smartphone sensor, user information, list of installed application on smartphone, random forest, Doc2Vec, ensemble

Student Number: 2016-21118